心理科学进展 2023, Vol. 31, No. 11, 1–13
Advances in Psychological Science

https://doi.org/10.3724/SP.J.1042.2023.001

基于网络分析的抑郁症产生与演变预测*

张伟霞[1] 席 敏[2] 阴甜甜[1] 王 成[1] 司书宾[3]

([1]西北工业大学体育部, [2]西北工业大学校医院, [3]西北工业大学机电学院, 西安 710072)

摘 要 抑郁症是现代社会亟需解决的公共健康问题，预防是应对该问题最有效的方式之一。有效预防的关键在于准确识别潜在抑郁症患者，捕捉抑郁状态发生变化的预警信号，及时采取预防措施。抑郁是由多种症状相互作用而成的网络系统，该网络的结构特征和动力特征能为抑郁症发生与演变的预测提供新的理论视角和可测量的指标。以如何预测抑郁症发生与演化的关键问题为切入点，从理论的角度论述症状网络与抑郁的关系，进一步考察抑郁症状网络的拓扑结构特征、临界现象相关指标在预测抑郁发作及突变中的表现力。为增加早期预警信号在抑郁状态预测方面的准确性，未来研究应当构建更系统、全面的网络，通过使用综合的或基于机器学习的预警指标，优化抑郁状态确定方法。

关键词 网络分析，抑郁症状演变，预测，临界现象，早期预警信号
分类号 R395

1 引言

抑郁症是一种常见的情感性精神障碍，给社会医疗、经济，个人健康与正常生活带来了沉重负担(Armbrecht et al., 2020; Keshavarz et al., 2022)。我国成人患抑郁症的比例约为 6.8%，但能够得到充分治疗的抑郁患者仅有 0.5% (Lu et al., 2021)。在这种形势下，与治疗相比，抑郁预防有着更为突出的临床价值。而有效预防的关键在于准确识别出潜在的抑郁患者，捕捉抑郁状态发生变化的预警信号，并及时应对(Fried et al., 2022)。因此，抑郁产生与变化的预测指标是抑郁预防中的核心科学问题。在本研究中，该问题的具体内容包括探索哪些指标能够预测抑郁症的产生，哪些指标预示抑郁状态的变化。

近年来，复杂系统的相关研究得到了长足的发展，在生态系统大规模灭绝、天气骤变，以及基础设施级联故障等方面有较为广泛的应用(Liu et al., 2022)。在此影响下，研究者提出从复杂系统的视角研究抑郁症(Borsboom, 2008; Cramer et al., 2016)，将抑郁症视为由多种症状为节点构成的网络系统。网络是由许多节点(node，节点代表物体或事件，比如抑郁症状的表现、个体或脑区等等)和边(edge，连接网络中节点之间的线)组成的系统。网络分析属于复杂系统科学的一部分，强调研究对象的复杂性和动态性，被认为是心理问题的新科学(new science of mental disorders) (Roefs et al., 2022)。

网络结构和动力性是复杂系统的典型特征，结构特征主要是网络的拓扑属性，而动力特征指网络在演化中表现出的规律，前者倾向从横向的角度解析复杂系统的静态特征，而后者更关注复杂系统的变化过程。对抑郁系统进行网络结构特征以及动力分析能为抑郁产生、变化的预测提供可量化的指标。一方面，基于网络结构特征的分析能揭示多种症状的关联关系及其相互影响而形成的系统(蔡玉清 等, 2020)，辅助确定网络关键节点(重要症状)，有利于从人群和干预靶点方面实现抑郁症的精准预防。另一方面，基于网络动力特征的预测，能在个体水平上预测抑郁状态的突变，为预防方案的个性化优化提供及时反馈(Fried et al., 2022)。本文围绕抑郁的产生与变化，

收稿日期：2022-10-26
* 西北工业大学特色文科发展计划——青年创新能力培养项目(GH030635)、西北工业大学教育教学改革研究项目(23GZ13163)资助。
通信作者：席敏, E-mail: ximin86269@nwpu.edu.cn

从理论和实证层面对基于网络分析方法的抑郁预测进行研究，重点探讨网络结构特征对抑郁产生的预测，以及系统动力特征对抑郁变化的预测。

2 网络结构与抑郁症产生

2.1 网络结构与抑郁症产生的理论解释

受还原论思想的影响，人们对抑郁症的早期探索延承了对生理疾病的理解，倾向于寻找尽可能精准的致病因素，并认为影响抑郁的多种因素是彼此独立的(Borsboom, 2008; Fried & Nesse, 2015)。类似第 21 染色体异常是唐氏综合征患者多种症状表现的病因，抑郁症被认为是诸多症状表现(比如心境低落、失眠、没有活力等等)的潜在共同原因，这就是传统的共因模型(common cause model) (Hofmann et al., 2016)。但是，与生理疾病不同，人们并没有找到抑郁症产生的明确因素，目前没有证据表明哪个因素是抑郁症产生的充分且必要条件。随着抑郁症多种症状非独立性、不可互换性的发现，传统研究方法的弊端逐渐凸显(Fried & Nesse, 2015)。于是，有研究者提出应当关注抑郁症状的相互作用，而非抑郁症生物学致因，并于 2008 年首次提出从网络的角度理解抑郁症(Borsboom, 2008)。

从网络的角度来看，抑郁症是由许多症状相互作用形成的复杂系统。抑郁的多种症状之间并不是相互独立的，一种症状会引发另一种症状的出现，比如情绪低落可能引起食欲减退。症状不是潜在疾病的被动表现形式，而是承担了积极主动参与的角色，这些症状的相互作用导致了抑郁的产生(Borsboom, 2008; Cramer et al., 2016)。复杂网络提供了一种新颖的精神病理的解释方法(Cramer et al., 2016; Hofmann et al., 2016)，得到了越来越多研究者的认可(Bringmann et al., 2013; De Beurs et al., 2021; Fried et al., 2017; Hayes & Andrews, 2020; McLaughlin et al., 2020; Robinaugh et al., 2020; Wittenborn et al., 2016)。

与传统观点相比，复杂网络对抑郁症产生或形成的解释更为全面和灵活。这是因为，抑郁的成因极其复杂，涉及生理、心理和社会等多个层面(McLaughlin et al., 2020)，仅从单一角度很难深入理解抑郁症形成，而网络则可以涵盖众多因素。在临床上，抑郁症的产生往往涉及多个症状(比如，睡眠障碍、肥胖和注意不集中等)相互作用形成复杂反馈环的过程(Hofmann et al., 2016)。比如，长期的失眠→疲倦→注意力下降，该循环的强化可能进一步诱发更多的症状关联，长期的失眠→疲倦→注意力下降→心境低落→深陷自责，诸多症状的共现就意味着抑郁发作。为清晰地展示抑郁症状之间的相互作用关系，我们使用包含抑郁量表公开数据库(CLHLS, http://chads.nsd.pku.edu.cn/sjzx/index.htm)的部分数据，将抑郁症状网络的可视化展现在图 1 中。从图 1 可以看出抑郁的多个症状表现存在一定的关系，比如孤独−无法继续生活−紧张害怕。由于图 1 是基于横断数据构建的无项网络，节点之间的关系不存在方向性，无法做出因果推论。如果是基于纵向数据构建的时序网络，可以进一步表明症状关系的因果关系，此类网络中连接节点的是由箭头的线，表示关系的方向性，详见 Aalbers 等(2019)中的图 2。

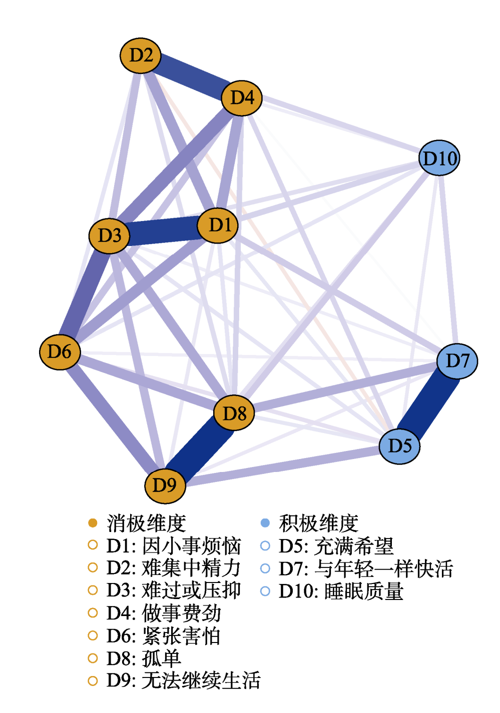


图 1 抑郁症状网络示意图

注：图中的节点(D1-D10)代表具体的抑郁症状，节点之间的连线代表症状之间的相互关系，节点间的蓝边代表症状间的正相关，红边代表负相关，连线越粗则相关性越高。[资料来源：根据公开数据库自创]

抑郁网络的观点得到了广泛支持，有充足的证据表明抑郁症的形成涉及多种症状的相互作用。首先，研究者发现，在与抑郁症状表现相关的

时序(Wichers, 2014)或横断数据中(Monk et al., 2022), 情绪、压力和行为状态等多个因素之间有明显关系; 其次, 与正常群体相比, 抑郁患者的症状网络连接密度更大(Cramer et al., 2016)。与抑郁状态缓解的人相比, 持续抑郁患者症状网络中的节点关系连接更强(van Borkulo et al., 2015)。而且, 症状的严重程度与节点连接存在显著关系(Heeren & McNally, 2018; van Rooijen et al., 2018)。最后, 询问临床专家可发现, 多个抑郁症状之间有密切的因果关系(Kim & Ahn, 2002)。在成功的精神类疾病治疗中, 治疗之后症状网络的连接明显减少(Madhoo & Levine, 2016)。

2.2　基于网络结构特征的抑郁产生预测

由于抑郁源于症状之间的相互作用, 分析抑郁症状的网络特征为预测抑郁发生提供了一种途径。从图论的角度分析, 抑郁网络的结构特征主要表现为网络拓扑属性, 比如连接性和节点中心性等, 网络连接性的主要指标为全局强度(global strength, 网络中所有边的权重绝对值之和)和网络密度(density, 所估计网络中边的数目占网络中所有节点可以构建出的总边数的比例) (陈琛 等, 2021), 节点中心性反映节点在网络中的重要程度。与社交网络、物流网络不同, 网络连通性或密度越大网络的信息传递和交互能力越强, 在症状网络中, 症状之间连接较弱的时候, 某些症状不会被其它症状激活, 网络整体韧性较大, 这种网络往往是健康的。由此, 网络密度或连通性越低, 预示抑郁症状严重程度越低(Borsboom, 2017)。

在网络密度方面, 重度抑郁患者比正常群体的连接密度更大(Pe et al., 2015)。整体连通性的预测能力暂没有得到充足的实证支持。一方面, 前瞻性研究表明, 基线阶段抑郁网络的连接程度能预测 2 年后的抑郁状态, 网络连接越紧密对应的个体状态越差(van Borkulo et al., 2015)。另一方面, 在青少年抑郁干预中, 尽管对干预响应较弱的群体在症状网络整体强度上比对干预响应较强的群体更高, 但差异不显著(Schweren et al., 2018)。此外, 有研究发现曲舍林抗抑郁药物介入 8 周后, 伴随抑郁症状的缓解, 症状网络连通性并没有减少, 反而增强了(Bos et al., 2018)。

研究之间存在差异的一个可能原因在于实验设计。van Borkulo 等人(2015)的研究为组间设计, 对比的是基线阶段正常组和持续抑郁组的差异, Bos 等人(2018)是组内设计, 涉及不止一次的症状评估。反复测量会带来反应偏差(Fried et al., 2016), 由于 Bos 等人(2018)没有设置对照组, 无法确定其显著差异源于干预还是重复测量。如果不是源于干预, 所谓相反的结果就不存在。这种猜测是存在可能的, 在一项考察抑郁干预方式有效性的研究中, 虽然丙咪嗪(一种抗抑郁药)组与安慰剂组在抑郁症状网络的连通性上存在显著差异, 但这种差异并非药物所致, 因为药物组的网络随时间变化不显著(Snippe et al., 2017)。

另一种可能的原因与有无干预(也就是系统的外界扰动或干扰)有关。有研究是在无干预条件下预测抑郁的发作(van Borkulo et al., 2015), 而其它研究则聚焦治疗介入后不同阶段的症状表现(Bos et al., 2018; Schweren et al., 2018), 不同预测时间点上的临界指标变化存在本质差异。具体来讲, 在无干预时, 系统更大的波动意味着状态恶化。治疗介入后, 系统的动荡看似是状态的恶化, 其实这种不稳定时期的波动是有益的, 因为这表明了抑郁系统有发生重构的可能性(Hayes et al., 2015; Olthof, Hasselman, Strunk, van Rooij et al., 2020)。根据 Hayes 等人(2015)的理论解释, 如果用于预测的数据的跨度恰恰处于系统重建阶段, 系统正在发生去稳定性与稳定性的重构, 该阶段的网络整体连通性有可能出现短暂的增强。由于无法确定最后一次测量究竟在哪个阶段, 这种解释需要进一步证实。

这些冲突的研究结果也从另一个角度提示, 在基于网络特征的抑郁预测中, 整体连通性或连接密度可能不是唯一指标。一项对比抑郁和非抑郁群体症状网络的研究并没有发现两组在连通性上存在差异, 却在社团结构上发现了组间差异, 表现为抑郁患者的社团结构更简单(Hakulinen et al., 2020)。也有研究发现, 基线阶段抑郁症状网络中心性(centrality)较强的症状比较弱的症状能更有力地预测抑郁发作(Boschloo et al., 2016)。这些结果说明, 社团结构、节点中心性, 以及其它尚未被开发的症状网络结构特征, 是预测抑郁产生的潜在指标。

3　网络的动力性与抑郁演变

3.1　临界现象与抑郁状态演变的理论解释

真实情景中的网络是动态的, 多种因素相互

作用可以改变网络弹性，推动网络系统的整体发展。当网络的发展超越了临界点(tipping point)，系统会从一种状态突然转向另一种状态，也就是相变(系统从一种状态到另一种状态的质变，比如水变成冰，正常与抑郁状态的转变) (Scheffer et al., 2009)。与网络发展的这一特点类似，抑郁症发展过程中的临床症状表现也是非线性的。大部分抑郁症患者的症状分布表现出了要么低、要么高的特征，患者自己也能感受到状态的突变(Helmich et al., 2020; Hosenfeld et al., 2015)。即便无明显外因出现，症状体验也会出现突然的、不连续的变化(Hayes et al., 2007)。传统方法很难解释这种突变，但网络演化可以。网络演化到临界点附近，即便是微小的扰动也有可能诱发系统发生质的变化(Boeing, 2016)。研究者利用动力系统理论的因果循环图生成了抑郁症作为动力系统的概念模型(Wittenborn et al., 2016)，进一步支持了抑郁症是一个动力系统的观点。

基于抑郁状态变化特征与网络演变规律的相似性，研究者将动力系统的一些概念应用到了抑郁症状的演变中。抑郁症被视为由多稳态构成的(alternative stable states)系统，健康和抑郁属于两种不同的状态。从一种状态(也被称为吸引子，attractor)转换到另一种的概率取决于吸引子的强度、扰动的类型、控制系统组织的参数，以及交替因子的强度(Hayes & Andrews, 2020)。在某些情况下，状态的转变会带来灾难性的后果，这一点在精神疾病中表现得尤为明显。因为从患病状态返回原有的健康状态较为困难，抑郁症一旦形成，在很大程度上是不可逆转的。仿真研究证明，系统相变发生后撤销干扰并不总会使系统重回原始状态(Cramer et al., 2016)。幸运的是，系统相变发生之前往往伴有早期预警信号的出现，如果能敏锐地捕捉到这些信号，就可以启动干预策略，能取得保护系统网络弹性，及时止损，降低抑郁发生率的作用，有重要的临床价值。为此，研究者总结了一些稳定存在于很多系统转折发生前的、普遍的早期预警信号(generic early warning signs)。常见的预警信号有两种，分别是临界波动(critical fluctuation)和临界慢化(critical slowing down)。

临界波动是指系统在临界点附近表现出的不规律且波动幅度较大的现象(Schiepek & Strunk, 2010)，它的出现往往伴随系统更大的变化性或复杂性。处于波动时期的系统是不稳定的，因此更能收纳新信息，有可能使系统变得更有适应力。基于临界波动提出的网络去稳定性转变模型(Network destabilization and transition model, NDT)可以很好地解释治疗介入抑郁系统的变化过程，为了解抑郁干预效果的产生及干预敏感期的确定提供了理论支撑。首先，在初始或基线阶段，与正常群体相比，抑郁群体的症状表现较多，症状之间相互作用强。从可视化网络中可以看出，抑郁网络节点多且彼此连接较强，而积极网络节点少且连接较弱(图 2A)；其次，在干预(比如体育锻炼、抗抑郁药物或心理治疗等)介入后的变化阶段，固化因素的减少允许新信息进入，与原有旧经验不一致的信息输入使得症状网络不稳定，抑郁网络系统处于波动状态。从图 2B 可以看出，该阶段抑郁症状会有短暂增加，这是治疗起作用的关键阶段。最后，干预之后的抑郁网络节点关联明显减少，积极网络被激活，该阶段的变化能预测治疗后的结果(图 2C)。干预的介入是一个扰乱旧模式，发展新的、更有适应性模式的过程(Hayes et al., 2015)。在图 2A、C 中，用带阴影的图形表示抑制变化的节点，节点较为稳固，说明系统是稳定的。图 2B 中，节点的稳定性被打破，用无阴影的图形表示开始变化发生的节点，说明系统是处于波动状态的。

临界慢化是指系统发展到临界点附近速度变慢的现象，图 3 从临界慢化的角度展示了抑郁状态演变的过程，图中的小球代表个体特定时间的状态。吸引域的形状(图 3A、3B 中呈现的凹陷部分)，尤其是深度，揭示了个体对外部扰动的回应。在图 3(A)中，系统是相对稳定的，吸引域很深，表明这种状态下的个体心理弹性较强。尽管小球会随外部扰动有一定变化，但除非扰动特别大(比如亲人离世)，否则小球不会从左边的吸引域滚动到右边的吸引域。在图 3(B)中，系统弹性低于(A)，吸引域的深度变浅，这种状态中的系统更容易“突变”，也就是突然转向右侧的另一种稳定状态。即使是很小的扰动，比如工作中的冲突，也能导致个体从正常状态过渡到抑郁状态。系统从 A 状态(抑郁状态)演化到状态 B (正常状态)，往往伴随临界慢化现象的出现。在这个过程中，随着吸引子力量减弱，吸引域变浅，小球被推离平衡位置后滚动的距离更远，再次回到稳定状态则

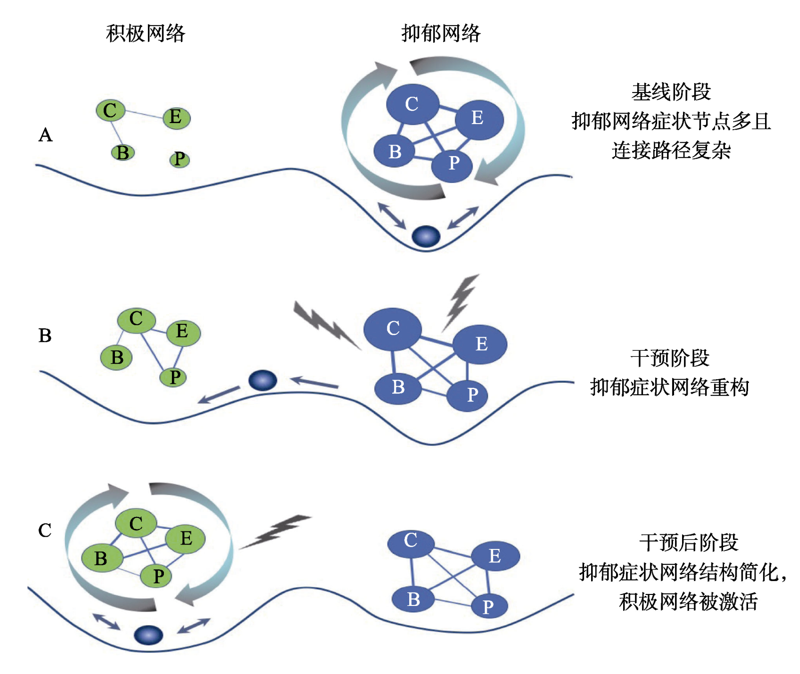
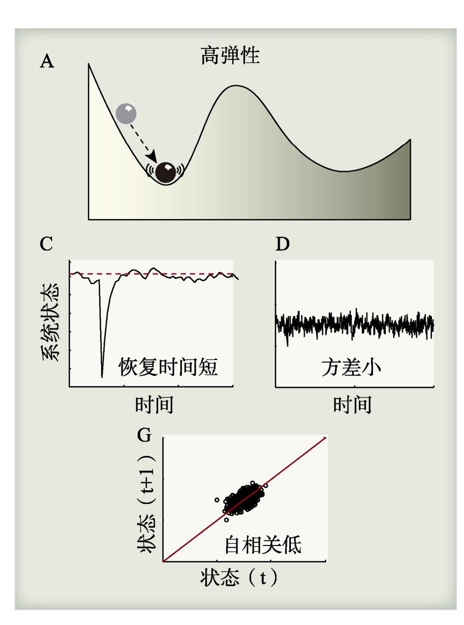


图 2　网络去稳定性和转变模型示意图

注：该图中的每一个节点以及节点之间的连线的意义与图 1 相同。(A)右边抑郁状态网络中节点连接更密切，展示了抑制变化发生的固化过程，左边积极的网络节点数量和连接明显减少；(B)治疗能够改变抑郁症状网络的稳定性，促进建设性的心理加工；(C)接受治疗以后，右侧抑郁网络被削弱。右侧积极网络的激活与运行能促进积极功能的螺旋上升。图中蓝色小球及其左右箭头代表状态，灰色闪电标识代表干预介入。[资料来源：Hayes & Andrews, 2020]



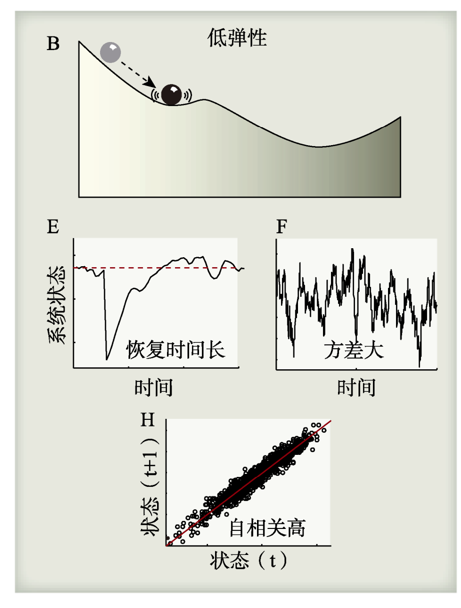


图 3　临界慢化与抑郁状态转变示意图[资料来源：基于 Scheffer et al (2012)绘制]

更慢。伴随临界慢化现象的常见指标包括恢复时间(系统复原所用时间)、自相关(t 与 t−1 时间点上的相关)、方差变异(t 与 t−1 时间点上差值的标准差)。当临界现象发生时，系统从扰动中恢复时长增大(C→E)，变异增加(D→F)，自相关变大(G→H)，这些指标的显著变化为抑郁的早期预警信号

提供了基础。

3.2 基于临界现象的抑郁变化预测

临界慢化和临界波动是系统的典型动力特征，是复杂系统发生相变之前的早期预警信号。由于临界现象是可计算的，而且有较为成熟的量化指标，在精神疾病预测方面表现出了潜力，众多实证研究尝试建立临界现象与抑郁发作或变化的关系。与网络结构特征的计算不同，临界现象的计算是建立在抑郁症状的时序信号基础上的，而非横断数据，这就涉及时序数据的采集。常用的方法为经验抽样法(experience sampling method, ESM) (Bastiaansen et al., 2020)。EMS 采集人们在日常生活场景下的动态数据，采集内容较为多样，比如，多条目的情绪评定、心率、体力活动和血压等(Gijzel et al., 2020)。相比传统的数据采集方法，在抑郁症的研究中，ESM 可以减少回忆偏差，提高研究的生态效度。

3.2.1 临界慢化与抑郁状态变化预测

首次明确提出将临界慢化作为抑郁状态变化早期预警信号的是 van de Leemput 等人。他们要求确诊抑郁患者和健康被试完成每天 10 次，连续 5~6 天的情绪评定任务(包括高兴、满足、悲伤和焦虑)，每个被试最终有 50~60 个时序的情绪评定值，基于这些时序数据分别计算每种情绪的自相关和方差变异，以此作为自变量。分别使用汉密尔顿抑郁测评量表和 SCL-90 界定接受治疗的抑郁症人群的状态，以及正常人群状态，以此作为为因变量。结果表明，在正常人群中，出现从正常状态到抑郁状态转变的被试在所有情绪的自相关和方差变异方面都显著高于未出现转变的被试。在抑郁群体中，所有情绪自相关的降低和方差变异的减少都能显著预测抑郁状态的恢复(van de Leemput et al., 2014)。临界慢化现象的出现不仅意味着系统在到达临界点前速度变慢，还意味着处于临界点附近的系统受扰动后恢复变慢。一项前瞻性研究发现，与没有变化的青少年相比，一年后心理障碍加重的青少年早在基线阶段就表现出了需要更多时间消除不良事件对情绪影响的现象(Kuranova et al., 2020)，说明基线阶段应对不良事件中表现出的临界慢化现象能预测一年后心理障碍的严重程度。该研究使用情绪的恢复速度，以更直接的方式证明了临界慢化对抑郁变化的预测力。

虽然 van de Leemput 等(2014)和 Kuranova 等(2020)的数据既可以进行组分析，也能在个体水平上计算早期预警信号，但研究者并没有展示个性化的结果，对临床应用价值是间接的。因为预警信号的表现力存在很大的个体差异(de Vries et al., 2019; Schreuder et al., 2022)，而群体研究的结果并不一定适用于个体(Schmiedek et al., 2020; Wright & Woods, 2020)。通过个体水平的计算，生成个性化预警信号不仅能防患未然，还能找到治疗的敏感期，提高治疗效果并为临床医生提供有效的反馈(Fried et al., 2022)。

在第一项个体水平的研究中，为确保研究的时间跨度涵盖抑郁状态的转折点，研究者监测了一名有重度抑郁发作史且抗抑郁药物正逐渐减少的患者，减少药物剂量会增加抑郁复发的风险，出现从正常到抑郁发作的状态转变。分析 EMS 收集的情绪自评问卷和每周一次的抑郁状态评定发现，在症状转变前的一个月出现了临界慢化现象，表现为 5 种情绪条目去趋势总分(summed detrended score)的自相关和方差显著上升(Wichers et al., 2016)。随后，该团队使用新的数据集对该结果进行了验证，他们收集了 6 名抗抑郁药物减少的抑郁患者每天 3 次，连续 3~6 个月的情绪自评数据。并基于每周一次的 SCL-90 测试，使用变点检验明确状态是否发生了变化。结果表明，仅有一名被试的状态发生了变化，这种状态的转变也伴随着临界慢化现象的出现，表现为心境低落自评分数自相关增大，方差变异和交叉相关增强，该结果趋势与先前完全一致(Wichers et al., 2020)。但是，该研究未汇报其余 5 名未发生症状突变的被试中是否也伴随类似的早期预警信号，无法推论临界慢化的出现与个体抑郁状态的转变是否存在稳定的关系。

在一项较大样本量的研究中，研究者对数据进行了更全面的汇报。41 名即将接受治疗的抑郁症患者完成每天 5 次，连续 4 个月的情绪自评任务，以及每周一次的抑郁状态评估。在整个治疗过程中，9 名被试的状态发生了转变，这种转变与临界慢化现象的关系较为复杂。在状态出现转变的被试中，其中有 8 名被试在至少一种情绪上表现出自相关增加，4 名被试在至少一种情绪上表现出方差变异增大。但是，在没有发生症状转变的 32 个被试中，有 20 名被试也在至少一种情绪中表

现出了自相关增强, 8 名被试在至少一种情绪中表现出方差增大(Helmich et al., 2022)。该研究说明, 并不是所有预警信号对所有人都有效, 存在某些预警信号对部分个体有效的现象, 这也进一步得到了其它研究者的支持(Bos et al., 2022)。在 11 名症状转变的患者中, 早期预警信号的出现增加了从正常状态到抑郁和躁狂状态转变的概率。也就是说, 没有早期预警信号的出现并不意味着在不久的将来不会发生状态转变(Bos et al., 2022)。除了预测临界点的到来, 临界慢化现象还能预测临界点之后转变的方向是抑郁恶化还是抑郁缓解, 预测的正确率为 52.31%(Schreuder et al., 2022)。

以上研究均使用主动的方式采集数据, 这对被试的配合度要求较高, 因为在患抑郁症时期, 找到许多患者愿意每天多次连续长时间段内填写问卷是一项挑战, 获取高质量数据需要大量的时间和资源投资。鉴于此, 有研究者使用可穿戴设备(腕动仪)进行主动数据采集, 这种方法能采集到更多的数据点, 但是无法直接测量参与者的情绪。分析 180 天体力活动数据的结果发现, 早期预警信号的表现力具有选择性。具体而言, 在 8 个状态转变的被试中, 7 名被试在症状转变前的 4 周表现出了早期预警信号。就普遍的早期预警信号(generic EWS, 包括方差和坡度)而言, 早期预警信号的指向总是与症状转变的方向一致。但是, 背景驱动的早期预警信号(context-driven EWS, 自相关)的指向却总是与 4 周后症状转变的方向相反(Kunkels et al., 2021)。这说明, 早期预警信号具体指标的选取会导致完全不同的预测结果。类似地, 另有研究者发现, 只有部分临界慢化量化指标能预测抑郁症状变化, 积极和消极情绪自相关的增加与抑郁症状恶化显著正相关, 但是, 方差变异与交叉相关均与抑郁症状的变化无关(Curtiss et al., 2021)。

3.2.2　临界波动与抑郁状态变化预测

虽然临界慢化与临界波动有一些共享的量化指标, 比如方差变异, 但二者在具体指标上存在差异。自相关是临界慢化的特异性指标, 而复杂性、熵是临界波动的特异指标。从本质上讲, 临界慢化强调临界点附近系统发展速度变缓, 而临界波动强调系统不稳定与稳定之间的转变。因此, 基于临界慢化的预测多为前瞻性研究(Bos et al., 2022; Helmich et al., 2022; Schreuder et al., 2022; Wichers et al., 2016; Wichers et al., 2020), 预测对象为抑郁状态的发展。而基于临界波动的预测多为干预研究(de Felice et al., 2022; Olthof, Hasselman, Strunk, Aas et al., 2020; Olthof, Hasselman, Strunk, van Rooij et al., 2020), 预测对象为干预后的效果。

根据 NDT 模型, 可以认为抑郁患者的状态被“卡”在了抑郁的状态下, 需要给该系统施加扰动, 导致原有的吸引子去稳定化, 由此系统将获取重构的希望, 在有可能出现的状态之间波动, 直到稳定状态形成(Hayes et al., 2015)。伴随该波动过程的信号是动态复杂性、熵, 以及方差变异的增加, 这得到了实证研究的支持。一项针对难治性抑郁患者的认知行为疗法干预结果表明, 无论基线阶段的症状如何, 情绪和行为功能在状态突变之前更大的波动都能预测 12 个月后更好的抑郁治疗结果(Yasinski et al., 2020)。与接受心理治疗后效果较差的组相比, 效果较好的组在治疗过程中表现出了更大的变异, 灵活性更大(de Felice et al., 2022)。这说明, 临界波动增强确实能预测抑郁干预的结果。心境障碍患者在治疗过程中表现出的动态复杂性增加也与更积极的治疗效果有关(Olthof, Hasselman, Strunk, Aas et al., 2020), 而且临界波动的出现能预测接下来 4 天内转变增加的概率(Olthof, Hasselman, Strunk, van Rooij et al., 2020), 为临床治疗中及时反馈的生成提供了可能。但是, 以上关于临界波动的研究均局限于组水平上, 临界波动能否在个体水平上预测抑郁患者预后的效果有待进一步研究。

临界慢化和临界波动的具体量化指标较多, 目前, 没有确切的结论表明哪个指标优于另外一个, 受场景类型影响非常大(Weinans et al., 2021)。具体指标的选择可以参考以下来自仿真模拟的结论：(1)检查所包含变量的自相关性。如果自相关与零无显著差异, 表明数据分辨率太低, 应使用基于方差的指标; (2)同时进行多个测量以确定数据的准确性。如果有准确性较低的数据(噪声大), 使用降维技术或使用平均自相关或方差; (3)在实际系统中, 噪声很可能是观测/测量噪声和系统噪声的组合。若系统噪声随时间变化, 应使用基于自相关的指标(Weinans et al., 2021)。

4　讨论与展望

从网络的角度阐释抑郁发生与演变的理论基

础，并基于此开展实证研究，为抑郁预测提供了量化方法。抑郁源于多种症状的相互作用，当相互作用形成的反馈循环足够强时，抑郁一触即发。整体连通性、网络密度、中心性和社团等为预测抑郁发作提供了具体指标。从演化角度来讲，抑郁症状的非线性发展符合网络系统相变的特征，相变前的临界现象为抑郁预测提供了量化方法。抑郁症状网络的结构特征和动力分析，为抑郁发生和变化提供了可量化的指标，为临床抑郁干预的及时性提供了保障。目前，该领域的研究仍然存在一些亟待解决的问题。

4.1 抑郁症状网络的构建有待完善

基于网络分析方法预测抑郁的实证研究缺乏系统和全面性，表现为网络节点内容的选取单一。在临界现象分析中，有研究者只测量情绪(van de Leemput et al., 2014)或将某些抑郁量表的条目作为节点，而有些研究的测量内容还包含睡眠和体力活动(Bos et al., 2022)。即便都是测量情绪，测量所用条目也有不同，有些研究的条目涉及积极、消极和不安三个维度(Wichers et al., 2016)，有些涵盖效价和唤醒组成的 4 个维度(van de Leemput et al., 2014)。其实，抑郁症状的表现较为丰富，涉及情绪、认知、行为等多个方面，使用单一的症状表现很难全面刻画该系统的状态，导致使用单条目或单维度的内容预测整体状态的变化较为困难(de Vries et al., 2019)。

在网络结构分析中，节点内容多为常用量表的具体条目，局限于心理变量，基因(Isvoranu et al., 2020)、生理信号等被忽视。有研究表明，与正常人群相比，抑郁患者的大脑结构及功能均有显著不同，基于这些显著的特征可以将他们从正常人群中区分出来(Dai et al., 2022; Zhu et al., 2022)，这说明某些独特的神经信号可以作为抑郁患者在生理水平上的表现形式。虽然抑郁脑网络的研究旨在确定抑郁的潜在神经基础，而抑郁症状网络的研究主要从症状水平揭示抑郁发生发展机制，但二者不应当被割裂。我们可以将神经活动信号以一种独特的方式加入症状网络中，比如节点之间连接强度的中介或调解变量，以此构建出大规模多因素网络(massively multifactorial symptom networks)，基于更加系统、全面的网络，深入详尽地阐释抑郁发生发展的机制(Borsboom et al., 2019)。

在网络构建中，理想的情况是把系统中所有层面的因素都纳入进去，这显然是不现实的。目前，没有研究明确表明应该测量什么(Eisele et al., 2021)。研究者建议节点的选择应当尽可能纳入建模预期现象所需的所有节点，排除同质性高的节点(Bringmann et al., 2022)。先前研究使用多条目情绪评定作为节点时，就出现了节点之间过多重合的现象，导致情绪动态性的预测力度不充分(Dejonckheere et al., 2019)。当节点内容足够全面、系统时，所构建出的网络必然是高维的，这不仅对节点数据的采样频率提出了要求，也对目前使用的分析方法提出了挑战。为确保数据结构的平衡性，节点的测量频率要尽可能保持一致。如果无法做到一致，可以使用连续时间模型解决(Bringmann et al., 2022)。此外，已有研究者提出了将高维系统动力性映射到低维系统动力性上的冗减理论(reduction theory)，该模型不仅能准确预测系统对各种扰动的响应，而且能准确定位系统失去弹性的临界点(Gao et al., 2016)，为网络分析提供了一种有效降维方法。未来研究要尽可能让节点内容丰富，全面融入心理、生理及神经信号，并从众多节点中提取综合信号用于计算。

4.2 临界现象预警指标与预测状态的关系不够稳健

临界现象在抑郁领域应用中面临的最大挑战是相关指标的出现与症状变化之间不是同步的。也就是说，临床表现与预警指标之间不存在明确的映射关系。从理论上讲，临界慢化与临界波动相关指标能有效预测抑郁发生与变化，但实证研究中二者的关系趋向不尽相同。一方面，这种关系的不稳定与临界现象的量化指标和方式有关。临界现象是一种复杂的现象，仅使用一个指标，比如自相关、交叉相关或方差变异，很难准确计算出早期预警信号的出现。常用的临界指标很容易受系统噪声的影响(Boettner & Boers, 2022)，而早期预警信号性能的表现受噪音影响很大(Dablander et al., 2022)，促使研究者开发新的指标。研究表明，使用包括变异系数、偏度系数、自相关和空间相关的综合指标比单一指标更能探测到系统临界转变的发生(Clements et al., 2019; Drake & Griffen, 2010)。除了在既有指标基础上开发出综合指标之外，机器学习也为系统相变的精准预测提供了方法(Ni et al., 2019)。最近的一项研

究使用深度学习, 能够在不依赖系统特异性的前提下, 以更高的灵敏度识别出临界点, 降低预测的假阳性(Bury et al., 2021), 这种算法为未来抑郁状态突变的预测提供了新的方法。

另一方面, 预警指标与预测对象关系不稳定可能与抑郁状态变化的界定有关。抑郁状态是预测的因变量, 直接关乎研究结果。目前常用的抑郁状态转变的界定大多基于抑郁诊断量表得分的变化, 比如量表得分在一周内变化 6 分(Bos et al., 2022; Kunkels et al., 2021), 或根据已获得状态的时序得分进行显著性检验, 通过比较多次评定获得的观测值是否发生显著变化确定状态的突变是否发生, 比如变点检测(Wichers et al., 2020)以及能捕捉非定时长内症状变化的 Duration-adjusted RCI 方法(Helmich et al., 2022)。使用这种单一的数据驱动的方法可能使得抑郁状态变化被遗漏或夸大(DeYoung & Krueger, 2018)。未来研究还应尽可能兼顾临床医生的诊断, 通过访谈等质性手段从参与者的角度寻找抑郁状态转变的迹象(Wichers et al., 2020)。结合自上而下和自下而上的方法, 多角度收集证据能更加准确地揭示参与者真实的状态。

最后, 由于系统的动力包括自身动力和交互动力(self and interaction dynamics) (Gao &Yan, 2022), 可以认为, 动力分析是建立在网络结构分析之上的。但是, 从目前的实证研究来看, 基于网络结构的预测和基于临界现象的预测处于人为的“割裂”状态, 没有研究在网络结构分析的基础上进一步分析系统动力。未来研究可以先分析症状网络拓扑属性, 找出网络中的关键节点, 并基于该节点的时序数据进行临界现象的监测分析, 从更加系统的角度构建抑郁预测的模型。

4.3　临床转化应用有待开发

收集个体抑郁症状的时序数据可以在个体水平上构建网络, 进行一系列网络结构特征和动力的分析, 其预警信号的生成能够警示抑郁状态未来的发展, 辅助临床干预人员确定干预介入的敏感期, 及时开展相关应对措施, 也能够及时将状态发展的趋势预告给当事人, 增强其自我认识和自我管理的能力。遗憾的是, 目前的研究主要集中于网络在抑郁领域适用性的论述以及实证检验上, 没有研究将预警信号以可读或可视的形式传递给医生或参与者, 缺乏相关平台或应用程序的搭建。这种平台的搭建需要基于数据驱动的算法和较为精准的时间选择, 确保预警信号生成是及时有效的, 而实时预警信号的机器学习算法已经实现(Fisher et al., 2021)。随着智能手机在精神病学领域的广泛使用(Gillan & Rutledge, 2021), 未来研究可以考虑像 EMS 收集数据那样, 通过智能手机装载 APP 或小程序, 发送预警信号。

参考文献

蔡玉清, 董书阳, 袁帅, 胡传鹏. (2020). 变量间的网络分析模型及其应用. *心理科学进展, 28*(1), 178−190.

陈琛, 王力, 曹成琦, 李根. (2021). 心理病理学网络理论, 方法与挑战. *心理科学进展, 29*(10), 1724−1739.

Aalbers, G., McNally, R. J., Heeren, A., De Wit, S., & Fried, E. I. (2019). Social media and depression symptoms: A network perspective. *Journal of Experimental Psychology: General*, *148*(8), 1454−1462.

Armbrecht, E., Shah, A., Schepman, P., Shah, R., Pappadopulos, E., Chambers, R., ... McIntyre, R. S. (2020). Economic and humanistic burden associated with noncommunicable diseases among adults with depression and anxiety in the United States. *Journal of Medical Economics, 23*(9), 1032−1042.

Bastiaansen, J. A., Kunkels, Y. K., Blaauw, F. J., Boker, S. M., Ceulemans, E., Chen, M., ... Bringmann, L. F. (2020). Time to get personal? The impact of researchers choices on the selection of treatment targets using the experience sampling methodology. *Journal of Psychosomatic Research*, *137*, 110211.

Boeing, G. (2016). Visual analysis of nonlinear dynamical systems: Chaos, fractals, self-similarity and the limits of prediction. *Systems, 4*(4), 37.

Boettner, C., & Boers, N. (2022). Critical slowing down in dynamical systems driven by nonstationary correlated noise. *Physical Review Research, 4*(1), 013230.

Borsboom, D. (2008). Psychometric perspectives on diagnostic systems. *Journal of Clinical Psychology, 64*(9), 1089−1108.

Borsboom, D. (2017). A network theory of mental disorders. *World Psychiatry, 16*(1), 5−13.

Borsboom, D., Cramer, A. O., & Kalis, A. (2019). Brain disorders? Not really: Why network structures block reductionism in psychopathology research. *Behavioral and Brain Sciences, 42*, e2, 1−63.

Bos, F. M., Fried, E. I., Hollon, S. D., Bringmann, L. F., Dimidjian, S., DeRubeis, R. J., & Bockting, C. L. (2018). Cross-sectional networks of depressive symptoms before and after antidepressant medication treatment. *Social Psychiatry and Psychiatric Epidemiology, 53*(6), 617−627.

Bos, F. M., Schreuder, M. J., George, S. V., Doornbos, B., Bruggeman, R., van der Krieke, L., ... Snippe, E. (2022). Anticipating manic and depressive transitions in patients with bipolar disorder using early warning signals. *International Journal of Bipolar Disorders, 10*(1), 1−14.

Boschloo, L., van Borkulo, C. D., Borsboom, D., & Schoevers, R. A. (2016). A prospective study on how symptoms in a network predict the onset of depression. *Psychotherapy and Psychosomatics, 85*(3), 183−184.

Bringmann, L. F., Albers, C., Bockting, C., Borsboom, D., Ceulemans, E., Cramer, A., ... Wichers, M. (2022). Psychopathological networks: Theory, methods and practice. *Behaviour Research and Therapy, 149*, 104011.

Bringmann, L. F., Vissers, N., Wichers, M., Geschwind, N., Kuppens, P., Peeters, F., ... Tuerlinckx, F. (2013). A network approach to psychopathology: New insights into clinical longitudinal data. *PLoS ONE, 8*(4), e60188.

Bury, T. M., Sujith, R., Pavithran, I., Scheffer, M., Lenton, T. M., Anand, M., & Bauch, C. T. (2021). Deep learning for early warning signals of tipping points. *Proceedings of the National Academy of Sciences, 118*(39), e2106140118.

Clements, C. F., McCarthy, M. A., & Blanchard, J. L. (2019). Early warning signals of recovery in complex systems. *Nature Communications, 10*(1), 1−9.

Cramer, A. O., Van Borkulo, C. D., Giltay, E. J., Van Der Maas, H. L., Kendler, K. S., Scheffer, M., & Borsboom, D. (2016). Major depression as a complex dynamic system. *PLoS ONE, 11*(12), e0167490.

Curtiss, J. E., Mischoulon, D., Fisher, L. B., Cusin, C., Fedor, S., Picard, R. W., & Pedrelli, P. (2021). Rising early warning signals in affect associated with future changes in depression: A dynamical systems approach. *Psychological Medicine*, 1−9.

Dablander, F., Pichler, A., Cika, A., & Bacilieri, A. (2022). Anticipating critical transitions in psychological systems using early warning signals: Theoretical and practical considerations. *Psychological Methods,* doi: 10.1037/met0000450

Dai, P., Xiong, T., Zhou, X., Ou, Y., Li, Y., Kui, X., ... Huang, Z. (2022). The alterations of brain functional connectivity networks in major depressive disorder detected by machine learning through multisite rs-fMRI data. *Behavioural Brain Research, 435*, 114058.

De Beurs, D., Bockting, C., Kerkhof, A., Scheepers, F., O’Connor, R., Penninx, B., & van de Leemput, I. (2021). A network perspective on suicidal behavior: Understanding suicidality as a complex system. *Suicide and Life‐Threatening Behavior*, *51*(1), 115−126.

de Felice, G., Giuliani, A., Pincus, D., Scozzari, A., Berardi, V., Kratzer, L., ... Schiepek, G. (2022). Stability and flexibility in psychotherapy process predict outcome. *Acta Psychologica, 227*, 103604.

de Vries, Y. A., Roest, A. M., Bos, E. H., Burgerhof, J. G., Van Loo, H. M., & de Jonge, P. (2019). Predicting antidepressant response by monitoring early improvement of individual symptoms of depression: Individual patient data meta-analysis. *The British Journal of Psychiatry, 214*(1), 4−10.

Dejonckheere, E., Mestdagh, M., Houben, M., Rutten, I., Sels, L., Kuppens, P., & Tuerlinckx, F. (2019). Complex affect dynamics add limited information to the prediction of psychological well-being. *Nature Human Behaviour, 3*(5), 478−491.

DeYoung, C. G., & Krueger, R. F. (2018). Understanding psychopathology: Cybernetics and psychology on the boundary between order and chaos. *Psychological Inquiry, 29*(3), 165−174.

Drake, J. M., & Griffen, B. D. (2010). Early warning signals of extinction in deteriorating environments. *Nature, 467*(7314), 456−459.

Eisele, G., Lafit, G., Vachon, H., Kuppens, P., Houben, M., Myin-Germeys, I., & Viechtbauer, W. (2021). Affective structure, measurement invariance, and reliability across different experience sampling protocols. *Journal of Research in Personality, 92*, 104094.

Fisher, A., Soyster, P., & Ashlock, L. (2021). Machine learning algorithms for generating early warning signals in real time. *Biological Psychiatry, 89*(9), S58−S59.

Fried, E. I., & Nesse, R. M. (2015). Depression sum-scores don’t add up: Why analyzing specific depression symptoms is essential. *BMC Medicine, 13*(1), 72.

Fried, E. I., Rieble, C., & Proppert, R. K. (2022). *Building an early warning system for depression: Rationale, objectives, and methods of the WARN-D study*. PsyArXiv. doi: 10.31234/osf.io/9qcvs

Fried, E. I., van Borkulo, C. D., Cramer, A. O., Boschloo, L., Schoevers, R. A., & Borsboom, D. (2017). Mental disorders as networks of problems: A review of recent insights. *Social Psychiatry and Psychiatric Epidemiology, 52*(1), 1−10.

Fried, E. I., van Borkulo, C. D., Epskamp, S., Schoevers, R. A., Tuerlinckx, F., & Borsboom, D. (2016). Measuring depression over time... Or not? Lack of unidimensionality and longitudinal measurement invariance in four common rating scales of depression. *Psychological Assessment, 28*(11), 1354−1367.

Gao, J., Barzel, B., & Barabási, A.-L. (2016). Universal resilience patterns in complex networks. *Nature, 530*(7590), 307−312.

Gao, T. T., & Yan, G. (2022). Autonomous inference of

complex network dynamics from incomplete and noisy data. *Nature Computational Science, 2*(3), 160−168.

Gijzel, S. M., Rector, J., van Meulen, F. B., van Der Loeff, R. S., van de Leemput, I. A., Scheffer, M., ... Melis, R. J. (2020). Measurement of dynamical resilience indicators improves the prediction of recovery following hospitalization in older adults. *Journal of the American Medical Directors Association, 21*(4), 525−530.

Gillan, C. M., & Rutledge, R. B. (2021). Smartphones and the neuroscience of mental health. *Annual Review of Neuroscience, 44*, 129−151.

Hakulinen, C., Fried, E. I., Pulkki-Råback, L., Virtanen, M., Suvisaari, J., & Elovainio, M. (2020). Network structure of depression symptomology in participants with and without depressive disorder: The population-based Health 2000−2011 study. *Social Psychiatry and Psychiatric Epidemiology, 55*(10), 1273−1282.

Hayes, A. M., & Andrews, L. A. (2020). A complex systems approach to the study of change in psychotherapy. *BMC Medicine, 18*(1), 197.

Hayes, A. M., Feldman, G. C., Beevers, C. G., Laurenceau, J.-P., Cardaciotto, L., & Lewis-Smith, J. (2007). Discontinuities and cognitive changes in an exposure-based cognitive therapy for depression. *Journal of Consulting and Clinical Psychology, 75*(3), 409−421.

Hayes, A. M., Yasinski, C., Barnes, J. B., & Bockting, C. L. (2015). Network destabilization and transition in depression: New methods for studying the dynamics of therapeutic change. *Clinical Psychology Review, 41*, 27−39.

Heeren, A., & McNally, R. J. (2018). Social anxiety disorder as a densely interconnected network of fear and avoidance for social situations. *Cognitive Therapy and Research, 42*(1), 103−113.

Helmich, M. A., Smit, A. C., Bringmann, L. F., Schreuder, M., Oldehinkel, A., Wichers, M., & Snippe, E. (2022). Detecting impending symptom transitions using early warning signals in individuals receiving treatment for depression. *Clinical Psychological Science*, 21677026221137006.

Helmich, M. A., Wichers, M., Olthof, M., Strunk, G., Aas, B., Aichhorn, W., ... Snippe, E. (2020). Sudden gains in day-to-day change: Revealing nonlinear patterns of individual improvement in depression. *Journal of Consulting and Clinical Psychology, 88*(2), 119−127.

Hofmann, S. G., Curtiss, J., & McNally, R. J. (2016). A complex network perspective on clinical science. *Perspectives on Psychological Science, 11*(5), 597−605.

Hosenfeld, B., Bos, E. H., Wardenaar, K. J., Conradi, H. J., van der Maas, H. L., Visser, I., & de Jonge, P. (2015). Major depressive disorder as a nonlinear dynamic system: Bimodality in the frequency distribution of depressive symptoms over time. *BMC Psychiatry, 15*(1), 222.

Isvoranu, A.-M., Guloksuz, S., Epskamp, S., van Os, J., Borsboom, D., & Investigators, G. (2020). Toward incorporating genetic risk scores into symptom networks of psychosis. *Psychological Medicine, 50*(4), 636−643.

Keshavarz, K., Hedayati, A., Rezaei, M., Goudarzi, Z., Moghimi, E., Rezaee, M., & Lotfi, F. (2022). Economic burden of major depressive disorder: A case study in Southern Iran. *BMC Psychiatry*, *22*(1), 577.

Kim, N. S., & Ahn, W.-k. (2002). Clinical psychologists' theory-based representations of mental disorders predict their diagnostic reasoning and memory. *Journal of Experimental Psychology: General, 131*(4), 451−476.

Kunkels, Y. K., Riese, H., Knapen, S. E., Riemersma-van der Lek, R. F., George, S. V., van Roon, A. M., ... Wichers, M. (2021). Efficacy of early warning signals and spectral periodicity for predicting transitions in bipolar patients: An actigraphy study. *Translational Psychiatry, 11*(1), 350.

Kuranova, A., Booij, S. H., Menne-Lothmann, C., Decoster, J., van Winkel, R., Delespaul, P., ... Rutten, B. P. (2020). Measuring resilience prospectively as the speed of affect recovery in daily life: A complex systems perspective on mental health. *BMC Medicine, 18*(1), 1−11.

Liu, X., Li, D., Ma, M., Szymanski, B. K., Stanley, H. E., & Gao, J. (2022). Network resilience. *Physics Reports, 971*, 1−108.

Lu, J., Xu, X., Huang, Y., Li, T., Ma, C., Xu, G., ... Zhang, N. (2021). Prevalence of depressive disorders and treatment in China: A cross-sectional epidemiological study. *The Lancet Psychiatry, 8*(11), 981−990.

Madhoo, M., & Levine, S. Z. (2016). Network analysis of the Quick Inventory of Depressive Symptomatology: Reanalysis of the STAR* D clinical trial. *European Neuropsychopharmacology, 26*(11), 1768−1774.

McLaughlin, K. A., Colich, N. L., Rodman, A. M., & Weissman, D. G. (2020). Mechanisms linking childhood trauma exposure and psychopathology: A transdiagnostic model of risk and resilience. *BMC Medicine, 18*(1), 1−11.

Monk, N. J., McLeod, G. F., Mulder, R. T., Spittlehouse, J. K., & Boden, J. M. (2022). Expanding the system: A brief psychosocial complex systems model of internalising disorder. *Journal of Affective Disorders, 303*, 297−300.

Ni, Q., Tang, M., Liu, Y., & Lai, Y.-C. (2019). Machine learning dynamical phase transitions in complex networks. *Physical Review E, 100*(5), 052312.

Olthof, M., Hasselman, F., Strunk, G., Aas, B., Schiepek, G., & Lichtwarck-Aschoff, A. (2020). Destabilization in self-ratings of the psychotherapeutic process is associated with better treatment outcome in patients with mood

disorders. *Psychotherapy Research, 30*(4), 520−531.

Olthof, M., Hasselman, F., Strunk, G., van Rooij, M., Aas, B., Helmich, M. A., ... Lichtwarck-Aschoff, A. (2020). Critical fluctuations as an early-warning signal for sudden gains and losses in patients receiving psychotherapy for mood disorders. *Clinical Psychological Science, 8*(1), 25−35.

Pe, M. L., Kircanski, K., Thompson, R. J., Bringmann, L. F., Tuerlinckx, F., Mestdagh, M., ... Gotlib , I. H. (2015). Emotion-network density in major depressive disorder. *Clinical Psychological Science, 3*(2), 292−300.

Robinaugh, D. J., Hoekstra, R. H., Toner, E. R., & Borsboom, D. (2020). The network approach to psychopathology: A review of the literature 2008−2018 and an agenda for future research. *Psychological Medicine, 50*(3), 353−366.

Roefs, A., Fried, E. I., Kindt, M., Martijn, C., Elzinga, B., Evers, A. W., ... Jansen, A. (2022). A new science of mental disorders: Using personalised, transdiagnostic, dynamical systems to understand, model, diagnose and treat psychopathology. *Behaviour Research and Therapy, 153*, 104096.

Scheffer, M., Bascompte, J., Brock, W. A., Brovkin, V., Carpenter, S. R., Dakos, V., ... Sugihara, G. (2009). Early-warning signals for critical transitions. *Nature, 461*(7260), 53−59.

Scheffer, M., Carpenter, S. R., Lenton, T. M., Bascompte, J., Brock, W., Dakos, V., ... Vandermeer, J. (2012). Anticipating critical transitions. S*cience*, *338*(6105), 344−348.

Schiepek, G., & Strunk, G. (2010). The identification of critical fluctuations and phase transitions in short term and coarse-grained time series—a method for the real-time monitoring of human change processes. *Biological Cybernetics, 102*(3), 197−207.

Schmiedek, F., Lövdén, M., von Oertzen, T., & Lindenberger, U. (2020). Within-person structures of daily cognitive performance differ from between-person structures of cognitive abilities. *PeerJ, 8*, e9290.

Schreuder, M. J., Wigman, J. T., Groen, R. N., Weinans, E., Wichers, M., & Hartman, C. A. (2022). Anticipating the direction of symptom progression using critical slowing down: A proof-of-concept study. *BMC Psychiatry, 22*(1), 1−13.

Schweren, L., Van Borkulo, C. D., Fried, E., & Goodyer, I. M. (2018). Assessment of symptom network density as a prognostic marker of treatment response in adolescent depression. *JAMA Psychiatry, 75*(1), 98−100.

Snippe, E., Viechtbauer, W., Geschwind, N., Klippel, A., de Jonge, P., & Wichers, M. (2017). The impact of treatments for depression on the dynamic network structure of mental states: Two randomized controlled trials. *Scientific Reports, 7*(1), 1−10.

van Borkulo, C., Boschloo, L., Borsboom, D., Penninx, B. W., Waldorp, L. J., & Schoevers, R. A. (2015). Association of symptom network structure with the course of depression. *JAMA Psychiatry, 72*(12), 1219−1226.

van de Leemput, I. A., Wichers, M., Cramer, A. O., Borsboom, D., Tuerlinckx, F., Kuppens, P., ... Aggen, S. H. (2014). Critical slowing down as early warning for the onset and termination of depression. *Proceedings of the National Academy of Sciences, 111*(1), 87−92.

van Rooijen, G., Isvoranu, A.-M., Kruijt, O. H., van Borkulo, C. D., Meijer, C. J., Wigman, J. T., ... de Haan, L. (2018). A state-independent network of depressive, negative and positive symptoms in male patients with schizophrenia spectrum disorders. *Schizophrenia Research, 193*, 232−239.

Weinans, E., Quax, R., van Nes, E. H., & Leemput, I. A. (2021). Evaluating the performance of multivariate indicators of resilience loss. *Scientific Reports, 11*(1), 1−11.

Wichers, M. (2014). The dynamic nature of depression: A new micro-level perspective of mental disorder that meets current challenges. *Psychological Medicine, 44*(7), 1349−1360.

Wichers, M., Groot, P. C., Psychosystems, E., & Group, E. (2016). Critical slowing down as a personalized early warning signal for depression. *Psychotherapy and Psychosomatics, 85*(2), 114−116.

Wichers, M., Smit, A. C., & Snippe, E. (2020). Early warning signals based on momentary affect dynamics can expose nearby transitions in depression: A confirmatory single-subject time-series study. *Journal for Person-Oriented Research, 6*(1), 1−15.

Wittenborn, A., Rahmandad, H., Rick, J., & Hosseinichimeh, N. (2016). Depression as a systemic syndrome: Mapping the feedback loops of major depressive disorder. *Psychological Medicine, 46*(3), 551−562.

Wright, A. G., & Woods, W. C. (2020). Personalized models of psychopathology. *Annual Review of Clinical Psychology, 16*, 49−74.

Yasinski, C., Hayes, A. M., Ready, C. B., Abel, A., Görg, N., & Kuyken, W. (2020). Processes of change in cognitive behavioral therapy for treatment-resistant depression: Psychological flexibility, rumination, avoidance, and emotional processing. *Psychotherapy Research, 30*(8), 983−997.

Zhu, J., Jiang, C., Chen, J., Lin, X., Yu, R., Li, X., & Hu, B. (2022). EEG based depression recognition using improved graph convolutional neural network. *Computers in Biology and Medicine, 148*, 105815.

Prediction of depression onset and development based on network analysis

ZHANG Weixia[1], XI Min[2], YIN Tiantian[1], WANG Cheng[1], SI Shubin[3]

([1] *Sports Department, Northwestern Polytechnical University*; [2] *Hospital, Northwestern Polytechnical University*;

[3] *School of Mechanical Engineering, Northwestern Polytechnical University, Xi'an* 710072, *China*)

Abstract: Depression is a public health problem that needs to be solved urgently in modern society, and prevention is one of the most effective ways to deal with this problem. The key of successful prevention is to accurately identify potential depression patients, capture warning signals indicating the state transition, and take preventive actions timely. Depression is a network composed of multiple symptoms interacting with each other. The structural and dynamic features of this network can provide new theoretical perspectives and measurable indicators for the occurrence and evolution of depression. Starting from the key issue of predicting the occurrence and changes of depression, this paper discusses the relationship between symptom networks and depression from a theoretical perspective, and further examines the performance of structural features and critical phenomena-related indicators of depression symptom networks in predicting depression onset and mutations. To increase the accuracy of early warning signals in predicting depression, future studies should construct more comprehensive networks, and optimize the method of determining depression states by using composite or machine learning based warning indictors.

Keywords: network, transition of depression, prediction, critical phenomenon, early warning signals